

НЕЙРОСЕТЕВОЙ АЛГОРИТМ ГЕНЕРАЦИИ ИЗОБРАЖЕНИЙ

*А.А. Салимова, студент, гр. 8Е72.
Томский политехнический университет
E-mail: aas251@tpu.ru*

Введение

Генеративные нейронные сети широко используются во многих отраслях, в том числе в области здравоохранения: трансформация МРТ изображения в КТ, преобразование медицинских снимков низкого качества в более четкие и детальные, использование в разработке лекарственных средств. Это одна из причин, почему развитие данного типа нейронных сетей на сегодняшний день является актуальным.

Целью работы являлось написание программного кода одного из типов генеративных моделей – вариационного автоэнкодера для генерации изображений из скрытого пространства состояний, сформированного согласно закону нормального распределения данных.

Описание алгоритма

Вариационный автоэнкодер (Variational Autoencoder, VAE) – генеративная модель, принцип работы которой основан на сжатии входных данных в скрытое пространство, а затем восстановлении из этого представления выходного сигнала [1]. Цель – получение на выходном слое отклик, наиболее близкий к входному.

Нейросеть автоэнкодера состоит из двух нейронных сетей – энкодера и декодера. Энкодер принимает входные данные и преобразует их, делая представление более компактным и сжатым. В свою очередь, декодер использует преобразованные данные для трансформации их обратно в оригинальное состояние.

Так как зашифрованные данные скрытого слоя имеют намного меньший размер, чем входные, энкодер неизбежно теряет часть информации. В то же время, нейросеть обучается сохранять как можно больше значимых деталей и откидывать второстепенные моменты [2].

Скрытое пространство вариационного автоэнкодера является непрерывным, что достигается следующим способом: энкодер выдаёт не один вектор определенной размерности, а два – вектор математического ожидания (среднего значения) μ и дисперсии (стандартного отклонения) σ [3]. Таким образом распределение точек в скрытом подчиняется нормальному закону распределения.

Благодаря этой особенности, входному объекту соответствует не одна точка в скрытом пространстве, а некоторая непрерывная область. Данный факт позволяет декодеру работать не с одним единственным вектором кодирования, соответствующим входным данным, а с их набором, благодаря чему в восстановление изображения вносится доля вариативности.

Гауссово распределение является наиболее простым с вычислительной точки зрения, имеет понятную приемлемую форму и полностью определяется двумя параметрами (математическим ожиданием и дисперсией). Практически любая точка, взятая в пределах полученного распределения будет на выходе декодера давать осмысленные изображения. По мере удаления от математического ожидания, точки встречаются реже.

Нейросеть автоэнкодера обучается как единое целое. В процессе обучения необходимо минимизировать сразу два критерия.

Первый – среднеквадратичная ошибка, позволяет проверить степень восстановления входных данных.

Второй критерий, так называемая дивергенция Кульбака-Лейблера [4], дает возможность оценить степень расхождения между двумя распределениями, т.е. определить, насколько распределение точек скрытого состояния напоминает вид нормального.

На основании вышеописанных положений, получаем следующую структуру вариационного автоэнкодера (рисунок 1). Случайное распределение, отражающее вектор скрытого состояний автоэнкодера, формируется по следующему выражению:

$$h = \sigma_n \cdot N + \mu, \quad (1)$$

где N – это генерируемая нормальная случайная величина с нулевым математическим ожиданием и единичной дисперсией.

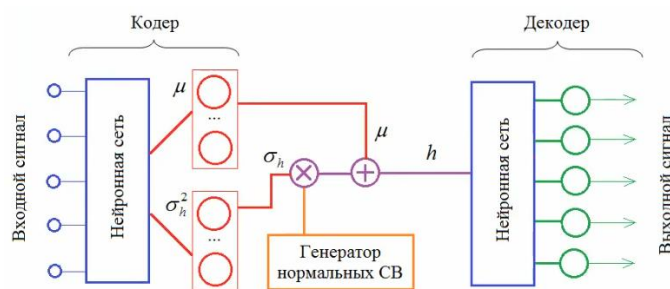


Рис. 1. Структурная схема VAE

Тестирование алгоритма

В результате реализован программный код на языке Python, отражающий структуру VAE. В ходе написания программы была использована открытая нейросетевая библиотека Keras.

На выходе энкодера было образовано скрытое пространство, имеющее следующее распределение (рисунок 2).




Рис. 2. Распределение состояний скрытого вектора

Тестирование программного кода проводилось на базе изображений рукописного текста MNIST. Результат работы алгоритма представлен на рисунке 3. В первом ряду представлены входные данные, во втором – восстановленные данные на выходе автоэнкодера.




Рис.3. Результат обучения вариационного автоэнкодера

Заключение

В результате проведения тестирования можно сделать вывод о том, что алгоритм вариационного автоэнкодера для генерации изображений является работоспособным. Пространство состояний скрытого вектора представляет собой единую цельную область без существенных разделений, поле его точек сформировано в соответствии с нормальным распределением.

Такой подход работы с данными позволяет изменять их вариации на выходе нейронной сети не случайным, а желаемым способом, определенным в ходе исследования скрытого пространства.

Список использованных источников

1. Как работает вариационный автоэнкодер (VAE) [Электронный ресурс]. – Режим доступа: <https://neurohive.io/ru/osnovy-data-science/variacionnyj-avtojenkoder-vae/> (дата обращения: 21.12.2020).
2. Автоэнкодеры в Keras, Часть 3: Вариационные автоэнкодеры (VAE) [Электронный ресурс]. – Режим доступа: <https://habr.com/ru/post/331552/>, свободный (дата обращения: 21.12.2020).
3. D. P. Kingma and M. Welling. An Introduction to Variational Autoencoders. Foundations and Trends in Machine Learning, vol. 12, no. 4, pp. 307–392, 2019.
4. Визуальная теория информации (часть 2) [Электронный ресурс]. – Режим доступа: <https://habr.com/ru/post/484756/> (дата обращения: 23.12.2020).